

Potenziale, Techniken und Algorithmen für die Zustandsdiagnose und -prognose bei LST-Elementen

Dr. Ing. René Schenkendorf,
Dipl.-Geoinf. Christian Linder,
Dipl.-Ing.-Inf. Thomas Böhm

alle Deutsches Zentrum für Luft- und Raumfahrt
e.V. (DLR), Institut für Verkehrssystemtechnik,
Braunschweig

1 Motivation

Die Betreiber von Eisenbahninfrastrukturen sehen sich mit einer Vielzahl von Herausforderungen konfrontiert. Vordergrün-

dig sind Wirtschaftlichkeit und Verfügbarkeit die allzeit präsenten Taktgeber. Im Hintergrund folgen die demographische Struktur des Personals, ein Mangel an qualifizierten Nachwuchskräften, wachsende Technologievielfalt, kürzere Innovationszyklen einer komplexer werdenden Technologie und neue Möglichkeiten aus IT-Trends. Zusätzlich ist der Betreiber durch die lange Nutzungsphase der Infrastruktur langfristig an die einmal angeschaffte Technik gebunden. Deshalb fällt der Instandhaltung eine besondere Schlüsselrolle zu. Sie




Abb. 1: Anlagennutzung bei verschiedenen Instandhaltungsstrategien

beeinflusst die Wirtschaftlichkeit und erst recht die Verfügbarkeit der Eisenbahninfrastruktur erheblich.

Von den verschiedenen Instandhaltungsstrategien (Abb. 1) gilt die zustandsorientierte Instandhaltung allgemein als effizienteste Strategie für langlebige, sicherheitsrelevante Investitionsgüter. Mit ihr kann die Funktionsdauer einer Anlage optimal genutzt werden, ohne die Verfügbarkeit zu gefährden. Die Voraussetzung dafür ist allerdings, dass der Anlagenzustand jederzeit bekannt ist. Theoretisch könnte der Zustand zwar durch eine manuelle Inspektion festgestellt werden, aber praktisch ist es unmöglich, ständig und überall im Bahnnetz das dafür nötige Wartungspersonal im Einsatz zu haben. Die Alternative ist ein kontinuierliches Monitoring der Infrastruktur durch entsprechende Sensorik.

Mit einem sensorgestützten Monitoring verändert sich die Herangehensweise des Infrastrukturmanagements nachhaltig. Grundsätzlich sind hierzu geeignete Technologien und Methoden zu entwickeln, die den Zustand von Infrastrukturelementen erfassen können. Die elektronisch erfassten Daten sind anschließend auszuwerten und die für die Zustandsdiagnose geeignetsten Informationen abzuleiten.

Das Prognose- und Zustandsmanagement (engl. Prognostics and Health Management – PHM) ist eine Ingenieursdisziplin, die sich explizit mit dieser Herangehensweise beschäftigt [1]. Ziel ist es, die Messungen bestmöglich zu nutzen und daraus Modelle für die Fehlerdetektion, -diagnose und -prognose zu entwickeln. Dies bedeutet, Störungen zu erkennen, ihre Ursache zu bestimmen und ihr Entstehen vorherzusagen. Eine detektierte Störung kann behoben werden. Mit der diagnostizierten Ursache kann dies schnell und effizient geschehen. Doch erst die Vorhersage kann eine Störung verhindern, indem sie es ermöglicht, dass in den anstehenden Instandhaltungsmaßnahmen optimale Handlungsalterna-

tiven eingeplant und umgesetzt werden können.

Eine zustandsorientierte präventive Instandhaltungsstrategie kann folglich dazu beitragen, die eingangs beschriebenen Herausforderungen zu meistern, indem die Instandhaltung effizienter wird und die Lebenszykluskosten der Infrastruktur gesenkt werden. Der vorliegende Beitrag gibt einen Überblick darüber, welche Potenziale zu erwarten sind und welche Techniken und Algorithmen hierbei zum Einsatz kommen können. Dabei fließen Erfahrungen aus verschiedenen Anwendungsprojekten des DLR-Instituts für Verkehrssystemtechnik mit ein. Unter anderem wurden und werden in den DLR eigenfinanzierten Projekten Next Generation Railway System I [2] und II sowie TrackScan-Sensoren und Methoden für die zustandsorientierte Instandhaltung der Eisenbahninfrastruktur erforscht.

Als von der EU finanziertes Projekt wurden in [3] Analyseverfahren für die automatische Gleislagefehlerdetektion auf Inertialmessdaten entwickelt, gemeinsam mit Partnern wie der DB Netz AG, Strukton, ProRail und der SNCF. Beim Aufbau der zentralen Diagnoseplattform DIANA (Diagnose- und Analyse-System) stand im Auftrag der DB Netz AG speziell die Zustandsanalyse von Weichen im Vordergrund.

Bevor jedoch die Einzelheiten der zustandsorientierten Instandhaltung näher besprochen werden, ist es hilfreich, sich die damit einhergehenden Begrifflichkeiten in Erinnerung zu rufen. Nur so können Missverständnisse und Fehlinterpretationen vermieden werden. Hierzu sind wichtige Bezeichnungen aus der VDI/VDE-Richtlinie 2651 [4] im Anhang (Tab. A1) noch einmal knapp zusammengefasst.

2 Potenziale

Nicht ohne Grund kommt der automatischen Zustandsüberwachung und Ferndia-

gnose bei Kraftwerksanlagen und Flugzeugen bereits heute eine zentrale Bedeutung zu [5, 6, 7]. Zahlreiche Veröffentlichungen belegen den hohen Durchdringungsgrad in diesen Branchen [5]. Die Erfahrungen zeigen hierbei, dass die zustandsorientierte, präventive Instandhaltung die essentiellen Anforderungen eines effizienten Instandhaltungsmanagements selbst für sicherheitsrelevante Systeme erfüllen kann. So ist zu attestieren, dass die Verfügbarkeit erhöht, die Anzahl der Störfälle reduziert und die Entstörung schneller wurde. Darüber hinaus zeigen Kosten-Nutzen Analysen, dass durch den Einsatz der zustandsorientierten, präventiven Instandhaltung die Lebenszykluskosten gesenkt werden können [6].

Ähnlich positive Effekte sind im Bereich der Eisenbahninfrastruktur zu erwarten und konnten bereits vereinzelt für ausgewählte Elemente der Leit- und Sicherungstechnik (LST) erzielt werden. Insgesamt betrachtet ist die präventive, zustandsorientierte Instandhaltung für die Betreiber von Eisenbahninfrastrukturen von großem Nutzen, sowohl monetärer als auch nicht monetärer Art [10, 11]. Der qualitative Nutzen der automatischen Zustandsüberwachung und Ferndiagnose ist vielfältig, offenbart sich jedoch dem Instandhalter am ehesten in weniger Störungen und dem Reisenden in weniger Verspätungen. Somit leistet die zustandsorientierte Instandhaltung einen wesentlichen Beitrag, den Verkehrsträger Schiene wettbewerbsfähiger zu machen.

Darüber hinaus kann die präventive, zustandsorientierte Instandhaltung, die Instandhaltungsorganisation selbst verbessern. In Instandhaltungszentren laufen die Daten zentral zusammen. Sie werden dort von Fachverantwortlichen bearbeitet, die dann das regionale Instandhaltungspersonal in das Feld entsenden. Bestenfalls geben sie den Einsatzkräften bereits ausreichend Informationen für eine gezielte und schnelle Entstörung mit an die Hand.

Ein weiterer qualitativer Nutzen ist, dass der Netzbetreiber insgesamt früher auf Probleme aufmerksam wird. Das müssen nicht zwangsläufig Störungen sein, sondern können auch Elemente sein, die nicht die geforderte Qualität oder Leistung erbringen. Rückkopplungen mit Herstellern und Lieferanten werden früher möglich.

Der quantitative Nutzen ist weitaus schwieriger zu bewerten und Bestandteil aktueller Forschung. Erste Ergebnisse bescheinigen aber auch hier eine signifikante Reduktion der Lebenszykluskosten. Eine Halbierung der Lebenszykluskosten um bis zu 50% scheint beispielsweise bei der Weiche unter gewissen Randbedingungen möglich zu sein [7]. Ähnliche Ergebnisse sind aus Frankreich (Hochgeschwindigkeitsstrecken der SNCF) bzw. aus der EcoSwitch-Studie [8] bekannt. Eine Verallgemeinerung auf weitere LST-Elemente bzw. auf sämtliche Betriebsbedingungen ist nur schwer möglich und bedarf weiterer Analysen.

Grundsätzlich ist es jedoch so, dass der größtmögliche Effekt, sowohl qualitativ als auch quantitativ, nur zu erzielen ist, wenn die präventive zustandsorientierte Instandhaltung auf einer übergeordneten, integrierenden LST-Diagnoseplattform erfolgt (Abb. 2). Erst die Betrachtung der Eisenbahninfrastruktur als Gesamtsystem kann optimale Instandhaltungsstrategien bereitstellen und ermöglicht, die tatsächlichen Ursachen einer Störung präzise zu diagnostizieren und zu lokalisieren. Dieser ganzheitlichen Betrachtungsweise wird beispielsweise im Fall der DIANA-Plattform innerhalb der DB Netz AG schon heute Rechnung getragen. Die prinzipiellen technischen Voraussetzungen als auch Algorithmen einer LST-Diagnoseplattform sind in den nachfolgenden Abschnitten beschrieben. Zusätzlich wird beschrieben, wie relevante Einflussgrößen durch qualitative Wirkungsketten identifiziert werden können und welche Methoden es gibt, diese zu erstellen.

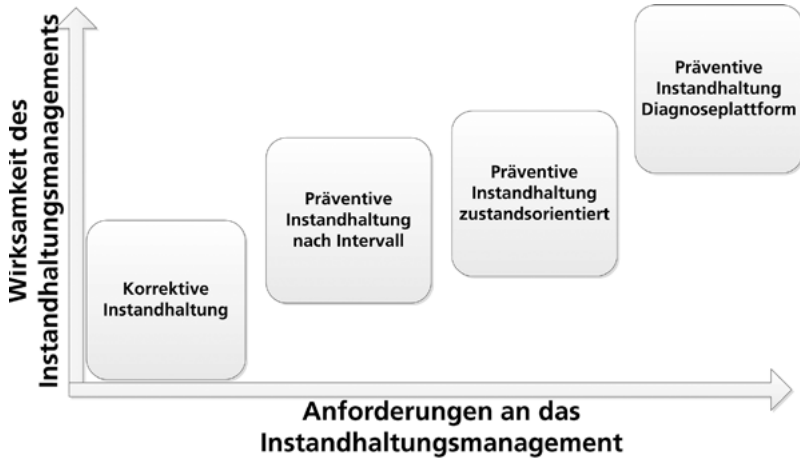


Abb. 2: Aufwand/Nutzen-Darstellung der verschiedenen Instandhaltungsstrategien

3 Techniken

Bei der technischen Realisierung von Diagnose- und Prognoseverfahren stellt sich zunächst die Frage nach geeigneten Daten und der dazu passenden Sensorik. Basierend auf den gewonnenen Daten, können mathematische Modelle generiert werden, die diagnostische bzw. prognostische Informationen liefern. Dabei ist die Auswahl der Messgrößen entscheidend, denn nicht jede Größe ist gleichzeitig ein relevanter Einflussfaktor auf den Zustand des betreffenden Elementes. Insbesondere unterscheiden sich oftmals die benötigten Daten für die Detektion bzw. die Diagnose von denen, die für die Prognose benötigt werden. Ein kleines Beispiel soll dies verdeutlichen: Eine Weiche ist mit einem Weichendiagnosesystem ausgestattet worden. Dieses System zeigt nun an, dass die Weiche innerhalb normaler Parameter funktioniert. Ferner ist das System in der Lage zu erkennen, dass die Messwerte beginnen zu drifteten und kann bestenfalls vorhersagen, wann – bei gleichbleibenden Randbedingungen – ein Grenzwert überschritten wird. Die Ursache für diesen Drift bleibt

jedoch verborgen. Angenommen, diese Ursache läge in der betrieblichen Belastung der Weiche und diese Belastung verringere sich zukünftig planmäßig, dann könnte das Diagnosesystem diese Reduktion der Betriebsbelastung nicht vorhersehen und würde aufgrund der aktuellen, lokal verfügbaren Datenlage einen falschen Instandhaltungszeitpunkt prognostizieren. Auf einer integrierten Instandhaltungsplattform, auf der diese Information verfügbar ist, wäre eine entsprechende Korrektur der Prognose möglich.

Wie dieses Beispiel zeigt, sollen für eine leistungsstarke Diagnose und Prognose in der Regel weitere, meist externe Informationen einbezogen werden. Die Identifikation dieser Größen ist jedoch nicht trivial und beruht idealerweise einerseits auf den Erfahrungen der Instandhalter, die die Systeme und deren Verhalten über die Zeit kennen, und andererseits auf denen der Hersteller, die ihrerseits um die konstruktive Gestaltung der Produkte wissen. Um diesen Erfahrungsschatz zu systematisieren, besteht die Aufgabe zunächst in der Erstellung von Ursache-Wirkung-Modellen von Einflüssen auf bestimmte Fehl-

zustände. Zur Generierung dieser Modelle stehen mehrere Methoden zur Verfügung, von denen hier zwei kurz angesprochen werden sollen.

Die erste Möglichkeit ist die Verwendung von Ursache-Wirkung-Diagrammen nach Ishikawa [9]. Diese Diagramme, auch Fischgrätendiagramme genannt, eignen sich besonders für die schnelle Visualisierung von Wirkzusammenhängen auf ein bestimmtes Ereignis, z.B. einen Fehlzustand. Die Abb. 3 illustriert zur besseren Verständlichkeit ein generisches Beispiel, bei dem ein exemplarischer Fehler durch Achslast, Temperatur und der Liegedauer sowie weiteren unbekannten Größen beeinflusst wird. Sind diese Werte identifiziert, können entsprechende Datenquellen identifiziert werden, was ebenfalls im Diagramm gezeigt wird. In der Praxis kommen

oftmals mehrere Datenquellen mit unterschiedlichen Vor- und Nachteilen in Frage. Die Verwendung dieses Diagrammtyps eignet sich insbesondere dann, wenn die Modelle in offenen Runden diskutiert werden sollen und möglichst viel Know-how von verschiedenen Mitarbeitern eingebracht werden soll. Gleichzeitig visualisiert die Grafik das resultierende Modell anschaulich.

Eine zweite, aufwändigere Methode zur Ermittlung der relevanten Einflussfaktoren ist die Failure Modes and Effects Analysis (FMEA) [10] oder die etwas erweiterte Failure Modes, Mechanics and Effects Analysis (FMMEA). Während bei der FMEA in den meisten Fällen, das Ziel darin besteht, aus Einzelanalysen eine Risikobewertung abzuleiten, kann die Methode jedoch so angepasst werden, dass aus der Ursachenanalyse

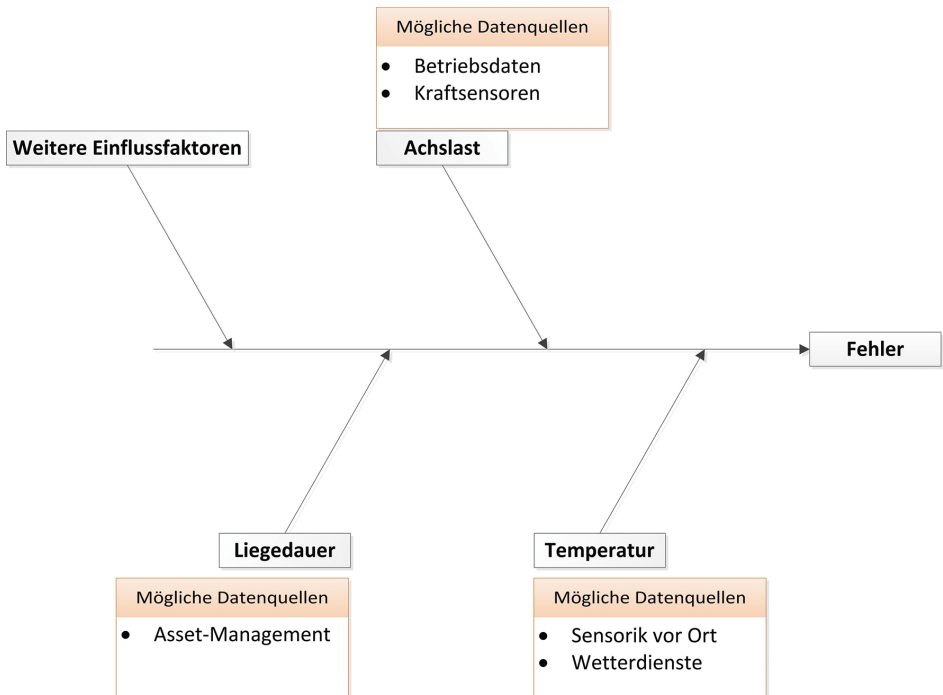


Abb. 3: Ishikawa-Diagramm

die Einflussfaktoren abzuleiten sind. Die Abb. 4 soll dies verdeutlichen. Da die Erstellung von FMEA vom Hersteller häufig ohnehin für die Zulassung durchgeführt wird, kann dies im Sinne der Synergienutzung hier weiterverwendet werden. Die FMEA liefert ein umfassendes Bild von Fehlermechanismen und deren Ursachen und offenbart eben die gesuchten Wirkzusammenhänge.

Sind schließlich die relevanten Einflussgrößen bekannt, kann abgeleitet werden, welche Datenquellen prinzipiell in Frage kommen, um diese Einflüsse zu quantifizieren. Dabei gibt es zahlreiche Möglichkeiten, von der Nutzung bereits vorhandener Sensorik über das nachträgliche Installieren der Messtechnik bis hin zur Abschätzung von Messgrößen aus anderen Daten, durch Berücksichtigung von z. B. stark korrelierten Werten.

Die Abb. 3 soll hier erneut als Beispiel dienen. Es soll gezeigt werden, dass es oftmals verschiedene Wege gibt, die benötigten Informationen zu erhalten. So kann die Information zur Achslast entweder vor Ort

durch Kraftsensoren gemessen oder aus den Datenbeständen des Betriebes ermittelt werden. Die Messung vor Ort hätte den Vorteil, die tatsächlichen Lasten und einwirkenden Kräfte mit beliebiger Genauigkeit zu erfassen, ist jedoch mit Investition und zusätzlichen Folgekosten für die Wartung der Sensorik verbunden. Bei der Ermittlung der Daten aus dem Betrieb ist zu beachten, dass die Auflösung der Daten den Anforderungen des Betriebes genügt, jedoch ggf. nicht denen für die Prognoseableitung. Andererseits sind diese Daten ohne weitere Installationskosten verfügbar. Insofern muss, wie im Beispiel illustriert, für jeden Einflussfaktor eine Abwägung für die geeignetste Datengewinnung getroffen werden.

Für die Art der Datenerhebung kann ein weiterer Gesichtspunkt eine Rolle spielen: Viele LST-Elemente besitzen bereits Sensorik und überwachen ihren Zustand auf dieser Datenbasis selbst. Vielfach bieten Hersteller die Produkte bereits mit integrierten Diagnoseeinheiten, teilweise sogar mit externen Diagnoserechnern, an. In vielen Fällen ermöglichen diese Systeme aus den vor Ort verfügbaren Daten eine Analyse des Ist-Zustandes und senden Alarme an beliebig konfigurierbare Stellen. Es ist jedoch davon auszugehen, dass die von den proprietären, lokalen Diagnosesystemen der Hersteller verwendeten Diagnosedaten nur ein Teil der relevanten Datensätze darstellt. Um das Beispiel in Abb. 4 wieder aufzugreifen, wird exemplarisch der Einflussfaktor der Liegedauer betrachtet. Die Datenquelle für diese Information ist offensichtlich externer Natur und kann vom System selbst nur schwer gemessen werden. Selbst wenn ein Zeitstempel fest in das System hineinprogrammiert ist, kann es sein, dass komplexe Elemente aus mehr als nur einem Bauteil bestehen. Würden einige davon durch Wartungsmaßnahmen getauscht, wäre die Information über die Liegedauer daraus nicht mehr ableitbar.

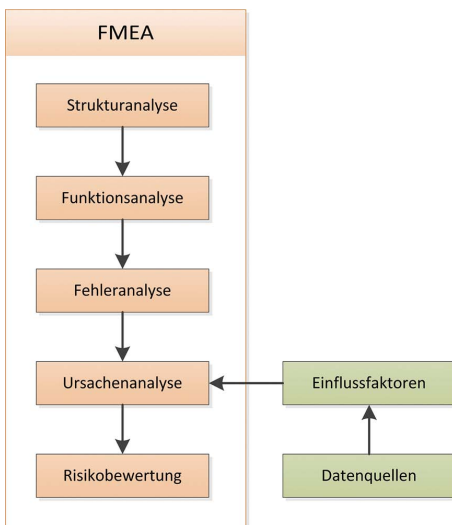


Abb. 4: FMEA-Ansatz

Dadurch wird klar, dass die benötigte Vielfalt an Daten für die spätere Prognosemodellierung so heterogen sein kann, dass eine lokale Selbst-Analyse der Elemente vor Ort nur eine bedingte Aussagekraft hat, da nicht alle benötigten Daten am Element selbst verfügbar sind. Dies wird spätestens aus den zuvor erarbeiteten Wirkungsketten und Ursache-Wirkung Modellen klar. Folglich kann die Entwicklung ganzheitlicher und leistungstarker Prognosemodelle nur auf einer zentralen, integrierten Plattform erfolgen, an der alle benötigten Informationen zusammenfließen und für die Diagnose als auch Prognose genutzt werden. Das Vorhandensein von Sensorik in den Feldelementen bringt dennoch nennenswerte Vorteile mit sich, denn erstens wird die Zulassung dieser Messtechnik automatisch als Teil des Gesamtsystems mit erwirkt und zweitens können diese lokalen Messdaten durch geringen Aufwand über standardisierte Schnittstellen auf eine zentrale Plattform übertragen werden. Soll Sensorik jedoch nachträglich verbaut werden, muss immer auch der zeitaufwändige und meist nicht einfache Nachweis der Rückwirkungsfreiheit geliefert werden. Weiterhin besteht zusätzlich die Möglichkeit bestimmte Wirkgrößen aus indirekten Messungen oder durch Messung korrelierter Werte abzuleiten. Dies wird häufig dann gemacht, wenn die zu untersuchende Komponente sehr komplex ist, wie beispielsweise im Bereich der Zuverlässigkeitsbetrachtung von Mikroelektronik, wie in (Kumar, Dolev, & Pecht, 2010) für Server Systeme dargestellt. Der Abschnitt 4 zum Thema Algorithmen geht unter anderem näher auf diese Art der Datenaufbereitung ein. Die Deutsche Bahn arbeitet aktuell an Lösungen zur Realisierung von entsprechenden Rahmenbedingungen [11] von denen insbesondere zwei maßgebliche Entwicklungen zu nennen sind. Zum einen bietet die Diagnoseplattform DIANA die Funktionalitäten einer modu-

laren Datensammelstelle, die in der Lage ist, Plug-In basiert verschiedene Module zur Datensammlung, sowie zur Datenauswertung zu integrieren. Hierbei können durch standardisierte Schnittstellen wie OPC-UA [11] auch heterogene Datenquellen integriert und in ein einheitliches Datenformat gebracht werden. Den zuvor erwähnten, bereits vorhandenen Diagnoseeinheiten in den Feldelementen bietet sich hier eine Chance. Denn je nachdem welche Informationen diese Feldelemente bereits liefern, könnten die Schnittstellen auf OPC-UA angepasst und ohne größeren Aufwand in DIANA integriert werden. Durch die modulare Struktur ist DIANA in der Lage neben den Mess- und Sensordaten auch externe Datenquellen wie betriebliche Informationen oder Umweltfaktoren einzubinden. Somit sind eben gerade diejenigen Voraussetzungen geschaffen, die ein ganzheitlicher Diagnose- bzw. Prognoseansatz benötigt. Zum anderen wird im Rahmen der Neu-Pro-Aktivitäten an einer neuen Stellwerksarchitektur gearbeitet, die ebenfalls modular strukturiert sein wird und in einer ersten Ausbaustufe als Pilotprojekt im Stellwerk Annaberg-Buchholz erfolgreich implementiert werden konnte. Als ein Teil des wesentlich größeren Gesamtkonzeptes für diese neue Stellwerksgeneration ist für die weitere Implementierung angedacht, einen Datenkanal zu den Feldelementen einzurichten, der – unabhängig vom SIL-4 gerechten Kommunikationskanal für die Stellbefehle – sicherheitsunkritische Informationen überträgt. Dieser Kanal kann dann für die Übertragung von Status- oder Messinformationen seitens der Feldelemente an eine zentrale LST Diagnoseplattform genutzt werden. Somit steht neben den Messdaten selbstüberwachender Feldelemente, der Diagnoseplattform mit standardisierten Schnittstellen auch der benötigte Datenkanal zur Übertragung der Daten bereit.

Diese exemplarisch hervorgehobenen, aktuellen Entwicklungen zeigen deutlich, dass die Bahn hervorragende Voraussetzungen schafft, um basierend auf dem Systemverständnis der Infrastrukturelemente, passende Wirkungsketten relevanter Einflussgrößen abzuleiten und anhand derer auf einer integrierten Plattform leistungsfähige Methoden für die präventive zustandsorientierte Instandhaltung zur Anwendung zu bringen. Die zur Verfügung stehende Bandbreite an Algorithmen für die rechnergestützte Datenanalyse wird nachstehend betrachtet.

4 Algorithmen

Nachdem im vorherigen Abschnitt die technischen Voraussetzungen der Datenerfassung näher beschrieben wurden, liegt der Fokus nun auf der eigentlichen Datenverarbeitung zum Zwecke der Diagnose und Prognose von LST-Elementen. Grundsätzlich müssen hierbei die beiden Aspekte des Datenmanagements und der Datenanalyse unterschieden werden.

Der zunehmende Einsatz von Sensoren für die Zustandserfassung von Infrastrukturelementen führt zunächst einmal zu neuen Herausforderungen im Instandhaltungsmanagement. So muss dafür Sorge getragen werden, dass die anfallenden und im Laufe der Zeit stetig zunehmenden Datenmengen zuverlässig kommuniziert und abgelegt werden. Da diese Problemstellung auf viele Anwendungsfelder zutrifft, gibt es hierzu bereits eine Vielzahl von Beiträgen [12], [13] und Techniken [14], so dass an dieser Stelle auf eine weiterführende Betrachtung verzichtet werden kann.

Die Datenanalyse selbst ist das Kernelement der präventiven, zustandsorientierten Instandhaltung und soll daher ausführlicher betrachtet werden. Wie im vorherigen Abschnitt beschrieben, kann eine zuverlässige, zustandsbasierte Instandhaltung nur erzielt werden, wenn die verwendete

Sensorik Eigenschaften des Infrastrukturelements erfasst, die einen Rückschluss auf den Zustand des Elements zulassen. Ist diese Bedingung erfüllt, spiegeln die so gewonnen Messdaten den aktuellen Zustand des Infrastrukturelements wider. Eine Änderung des Zustandes, also die Ermittlung eines Symptoms, wird durch den Vergleich von aufeinanderfolgenden Messungen bzw. Messreihen erkennbar. Wichtig hierbei ist zu erwähnen, dass nur selten die einzelnen Datenpunkte von aufeinanderfolgenden Messreihen verglichen werden, vielmehr werden charakteristische Merkmale der Messreihen gegenübergestellt. Solche Merkmale einer Messkurve sind beispielsweise:

- der Flächeninhalt unter einer Messkurve,
- Maxima/Minima einer Messkurve,
- Mittelwert der Messdatenpunkte,
- Varianz/Streuung der Messdatenpunkte,
- Frequenzanteile einer Messkurve.

Eine aus den Merkmalen gewonnene, weitere für die Zustandsdiagnose hilfreiche, jedoch oft vernachlässigte Größe ist die Korrelationseigenschaft der Merkmale untereinander. Insbesondere durch das Einbeziehen dieser Korrelationseigenschaft werden Änderungen des Zustandes frühzeitig offenbart bzw. werden überhaupt als Abweichung erkennbar. Dieser Effekt ist in der Abb. 5 verdeutlicht. In den beiden individuellen Merkmalen, A und B genannt, sind augenscheinlich keine Auffälligkeiten und somit mögliche, erste Indikatoren für eine Degradation des betrachteten Infrastrukturelements erkennbar. Vielmehr sieht man hier die natürliche Schwankung in den erfassten Messdaten, welche durch Messrauschen und Temperatureinflüsse hervorgerufen sein kann. Bezieht man jedoch die Korrelation der beiden Merkmale ein, sind deutliche Abweichungen in der Korrelationseigenschaft erkennbar (Abb. 6). Ist ein Anstieg (Abfall) des ersten Merkmals A immer mit einem Anstieg

(Abfall) des zweiten Merkmals B verbunden, deutet ein plötzlich Gegenteiliges Verhalten auf eine Änderung des Zustandes des Infrastrukturelementes hin und somit auf eine sich anbahnende Störung.

Wie im vorhergehenden Abschnitt aufgezeigt, ist bei der datengetriebenen Zustandsbeurteilung zu beachten, dass viele Merkmale durch Umweltfaktoren beeinflusst werden. Das heißt, dass Änderungen in den betrachteten Merkmalen bzw. deren Korrelation allein durch sich ändernde Umweltfaktoren wie der Temperatur hervorgerufen werden können. Um zuverlässig unterscheiden zu können, ob eine Merkmalsänderung der Degradation oder der Temperaturschwankung bzw. weiteren Einflussfaktoren geschuldet ist, müssen die wesentlichen Umweltfaktoren messtechnisch erfasst und in die Datenanalyse einbezogen werden. Die Diagnose wird somit robust gegenüber diesen Umweltfaktoren, welche auch als Störgrößen aufgefasst werden können. Weniger Falschmeldungen sind hierdurch zu erwarten. Ebenfalls sollten betriebliche Einflussfaktoren berücksichtigt werden, sofern diese einen unmittelbaren Einfluss auf die betrachteten Merkmale haben. Offensichtlich steigen die Anzahl der zu betrachtenden Merkmale und deren Einflussfaktoren bei einer umfassenden Datenanalyse schnell an, ein manuelles Auswerten und Bewerten ist nur in wenigen Fällen möglich. Werden in der Praxis eine Vielzahl von Infrastrukturelementen überwacht, ist ein manuelles Auswerten gar unmöglich. Abhilfe hierbei können Verfahren der automatischen Zustandsüberwachung in Kombination mit Methoden der Dimensionsreduktion schaffen. Im Allgemeinen wird bei der automatischen Zustandsüberwachung ein mathematisches Modell erzeugt und basierend auf historischen Datenaufzeichnungen geeignete Alarmgrenzwerte festgelegt. Einmal konfiguriert, ermöglicht dieser Ansatz eine automatische Zustandsüber-




Abb. 5: Änderungen in den einzelnen Merkmalen




Abb. 6: Änderung in der Korrelation

wachung. Ein manuelles Eingreifen wird somit erst beim Überschreiten der Alarmgrenzwerte nötig. Die Methoden der Dimensionsreduktion wiederum zielen darauf ab, die Informationsmenge, welche in den betrachteten Merkmalen enthalten ist, auf ein handhabbares Maß, sowohl für die manuelle als auch für die algorithmische Auswertung, zu reduzieren (Abb. 7). Anhand des generischen Beispiels ist ersichtlich, dass beispielsweise die Hauptkomponentenanalyse (engl. Principle Component Analysis – PCA) nur die wesentlichen Merkmalseigenschaften betrachtet, nicht jedoch alle detaillierten „Schattierungen“. Bei der statistischen Prozessüberwachung (engl. Statistical Process Control – SPA) geht man noch einen Schritt weiter, indem man nur zwischen bekannten Merkmals-




Abb. 7: Dimensionsreduktion

eigenschaften bzw. völlig abweichendem Verhalten differenziert. Dies bedeutet, dass nicht alle individuellen Merkmale beobachtet werden. Vielmehr konzentriert sich die Auswertung auf wenige, ausgewählte Repräsentanten dieser Merkmale. Die zur Verfügung stehenden Algorithmen für die Zustandsüberwachung und die Dimensionsreduktion sind so vielfältig wie die zu

überwachenden LST-Elemente selbst. Eine Übersicht ist in der Abb. 8 zu sehen. Diese stellt nur einen Auszug dar und erhebt keinen Anspruch auf Vollständigkeit. Eine ausführliche Beschreibung aller dort gezeigten Ansätze ist nicht die Absicht des aktuellen Beitrages, vielmehr wird auf folgende Referenzen verwiesen [15, 16, 17]. Aus Sicht der Autoren sind jedoch insbe-

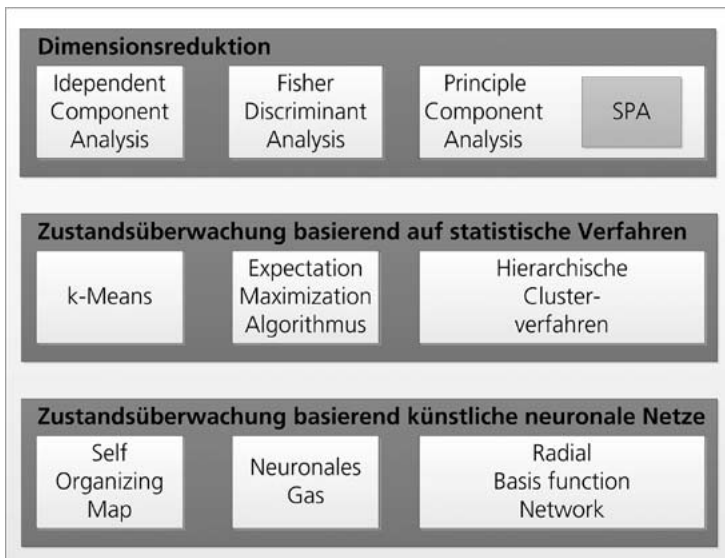


Abb. 8: Übersicht Algorithmen

sondere Methoden aus der statistischen Prozessüberwachung [18] exemplarisch für den Bahnbereich herauszustellen. Die Grundidee bei der statistischen Prozessüberwachung ist, dass alle ermittelten Merkmale eines Infrastrukturelementes, dies können unter Umständen weit mehr als 20 an der Zahl sein, als auch die mit einzubeziehenden Umweltfaktoren auf nur zwei repräsentative Größen abzubilden. Eine dieser Größe repräsentiert hierbei die Veränderungen in den Merkmalswerten selbst. Die zweite Größe detektiert Abweichungen in den Korrelationseigenschaften der Merkmale bzw. zu den erfassten Umweltfaktoren. Anhand allein dieser beiden Größen ist es möglich, eine Zustandsüberwachung zu implementieren. Hierbei werden mit Hilfe eines repräsentativen Satzes von historischen Messdaten entsprechende Alarmgrenzwerte statistisch bestimmt. Bei der angestrebten Diagnose werden dann anhand der aktuellen Messdaten genau diese zwei repräsentativen Größen ermittelt und mit den vorab bestimmten Grenzwerten verglichen, es erfolgt eine Symptomermittlung. Werden die Grenzwerte überschritten, wird automatisch eine Fehlermeldung generiert. Der Vorteil bei diesem Vorgehen ist, dass abgesehen von der Auswahl geeigneter Messgrößen, kein weiteres Expertenwissen über das zu diagnostizierende Infrastrukturelement nötig ist. Weiterhin sind die darauf aufbauenden Fehlermeldungen mit Methoden des Data Minings automatisiert erstellbar. Ebenfalls werden keine Messdaten über bereits degradierte und fehlerhafte Elemente benötigt. Sollte diese Information jedoch vorhanden und das dazugehörige Fehlerbild eindeutig bekannt sein, können Verfahren aus dem Bereich des überwachten Lernens [15] eingesetzt werden. Diese weisen dann im Idealfall nicht nur darauf hin, dass sich der Zustand des Infrastrukturelementes verschlechtert hat, sondern benennen die vorab erlernte Fehlerursache explizit. In

den meisten Fällen fehlt jedoch die nötige Datengrundlage hierzu, so dass die zuvor beschriebenen Methoden (unüberwachtes Lernen bzw. statistische Prozessüberwachung) als einzig praxistaugliche Alternativen übrig bleiben – Stand heute. Dennoch sind diese Verfahren bereits in der Lage, einen essentiellen Beitrag für die präventiven, zustandsbasierten Instandhaltung zu leisten. Mit ihnen ist es bereits heute möglich, dass:

- sich anbahnende Störungen erkannt werden (Symptombildung),
- statistisch abgesicherte Fehlergrenzen bestimmt werden können,
- die Qualität der LST-Elemente beurteilt werden kann.

Ein weiterer Vorteil dieser Methoden ist, dass sie ebenfalls für die Zustandsprognose verwendet werden können. Ging es bisher ausschließlich um die Diagnose, also der Beurteilung des aktuellen Zustands eines Infrastrukturelements basierend auf den historischen und den aktuellen Messdaten bzw. den daraus abgeleiteten Merkmalen, ist mit der Prognose auch die zukünftig zu erwartende Veränderung in den Merkmalen im Fokus der Betrachtung. Dazu werden die für die Zustandsbeurteilung relevanten Größen für einen zukünftigen Zeithorizont extrapoliert. Die verbleibende Zeitspanne (Remaining Useful Life – RUL) bis zu der ein vordefinierter Grenzwert überschritten wird, kann somit bestimmt werden. In der Literatur ist eine Vielzahl von möglichen Extrapolationsansätzen zu finden [19, 20]. Eine häufig in der Praxis anzutreffende, algorithmische Umsetzung dieser Extrapolation/Prädiktion basiert auf Kalman Filter Verfahren [21, 22]. Diese bieten den entscheidenden Vorteil, dass Unsicherheiten bei der Extrapolation mit einbezogen werden können, Konfidenzgebiete (Vertrauensbereiche) der rechnergestützten Vorhersage sind, wie in Abb. 9 angedeutet, somit ermittelbar. Das Berücksichtigen von weiteren Unsicherheitsfakto-




Abb. 9: Prognose

ren (zukünftige, betriebliche Faktoren als auch Umwelteinflüsse) ermöglicht noch zuverlässigere Prognosen und ist Gegenstand aktueller Forschung.

Insbesondere die Zustandsprognose eröffnet somit neue Strategien bei der Planung von Instandhaltungsmaßnahmen. Sind die Zeitspannen bis zu den erwarteten Störungen bekannt, können alternative Handlungsmaßnahmen ausgewertet und umgesetzt werden. Auch diesen Prozess des optimierten Instandhaltungsmanagements können geeignete Algorithmen unterstützen [23], sie sind jedoch nicht Gegenstand des vorliegenden Beitrages.

5 Zusammenfassung

In dem vorliegenden Artikel wurde aufgezeigt, mit welchen Mitteln aus Technik und Algorithmen die präventive, zustandsorientierte Instandhaltung dazu beitragen kann, die aktuellen Herausforderungen der Infrastrukturbetreiber besser zu meistern. Anhand einer wohlüberlegten Auswahl von Sensorsystemen, Schnittstellen, Protokollen und Datenanalysealgorithmen kann es dem Infrastrukturbetreiber schon heute gelingen, das Verhältnis von Wirt-

schaftlichkeit und Verfügbarkeit zu seinen Gunsten zu ändern. Das Einrichten und Verwenden einer übergreifenden LST-Diagnoseplattform wird hierbei das größte Potenzial zugesprochen. Durch technikübergreifende Zustandsanalyse verringert sich die Auswirkung der Technikvielfalt. Und letztlich haben Störungen eine geringere negative Wirkung oder können ganz verhindert werden. Über die rein technische Betrachtung hinaus, sind weitere positive Effekte zu erwarten. Durch eine automatische Anlagenüberwachung werden die Instandhalter von Routineaufgaben entlastet und können sich auf die wichtigen Problemfälle konzentrieren. Weiterhin ist davon auszugehen, dass durch einen gewissen Anteil an Büroarbeit am PC die Tätigkeit für junge Fachkräfte attraktiver wird, ein nicht zu vernachlässigender Faktor bei der aktuellen demographischen Entwicklung. Neben den genannten Vorteilen einer präventiven, zustandsorientierten Instandhaltung sollte jedoch auch beachtet werden, dass mit dieser Art der Zustandsdiagnose/-prognose eine zum Teil zusätzliche technische Infrastruktur geschaffen wird. Das System zum Sammeln, Organisieren und Managen der Daten wird somit selbst zu

einer kritischen Infrastrukturkomponente und muss daher von vornherein so ausgelegt sein, dass eine Selbstüberwachung möglich ist.

Quellen

- [1] S. Uckun, K. Goebel und P. J. Lucas, „Standardizing research methods for prognostics“, Piscataway, NJ, IEEE, 2008, pp. 1 – 10.
- [2] K. Lemmer, Hrsg., Next Generation Railway System, Bd. 18, Braunschweig: DLR-Institut für Verkehrssystemtechnik, 2012.
- [3] G. Baumann, C. Linder und R. Schenkendorf, „Inspection of track from in-service freight trains“, 2013. [Online]. Available: http://www.automain.eu/IMG/pdf/d3.1._f-4.pdf.
- [4] VDI/VDE-Gesellschaft für Mess- und Automatisierungstechnik, „Plant Asset Management (PAM) in der Prozessindustrie – Definition, Modell, Aufgabe, Nutzen“, Berlin, 2008.
- [5] R. Rao, „COMADEM 2013; Proceedings of the 26th International Congress on Condition Monitoring and Diagnostics Engineering Management“, Helsinki, Fin, 2013.
- [6] N. Hölzel, T. Schillin und S. Langhans, „Aircraft lifecycle cost-benefit analysis of PHM systems“, *International Meeting for Aviation Product Support, Victorville, USA*, 11 2010.
- [7] R. Knewitz, „2. Internationaler S+D-Kongress: Verfügbarkeit – Diagnose – Instandhaltung“, *Signal + Draht*, Bd. 94, Nr. 12, pp. 26-37, 2002.
- [8] S. Jovanovic und W.-J. Zwanenburg, *Switches and Crossings Management System: EcoSwitch*, European Rail Research Institute, Hrsg., Paris.
- [9] J. Kern, Ishikawa Diagramme. Ursache-Wirkungs-Diagramme, Grin Verlag GmbH, 2009.
- [10] D. Deutsche Gesellschaft für Qualität e.V., FMEA-Fehlermöglichkeits und Einflussanalyse, Beuth, 2004.
- [11] M. Leining und B. Elsweiler, „Signaltechnik 4.0 – Industrialisierung der Signaltechnik“, *Deine Bahn*, 2014.
- [12] F. Köster und N. Ulf, „Leistungsfähiges Datenmanagement als Rückgrat einer menschenzentrierten Entwicklung von Automation/Assistenz“, 24. VDI/VW-Gemeinschaftstagung – Integrierte Sicherheit und Fahrerassistenzsysteme, pp. 219-226, 29 10 2008.
- [13] C. Decker, „Analyse und Monitoring eines verteilten Datenmanagements“, *Hochschulschrift / Fachhochschule Heidelberg*, 2008.
- [14] IBM, „Tapping the power of big data for the oil and gas industry“, *IBM Software / White Paper*, 2013.
- [15] H. Petersohn, Data Mining, München, Wien: Oldenbourg, 2005, p. 330.
- [16] C. Bishop, Pattern Recognition and Machine Learning, Springer, 2007.
- [17] E. Alpaydin und S. Linke, Maschinelles Lernen, Oldenbourg Wissenschaftsverlag, 2008.
- [18] A. Schulze und E. Dietrich, Statistische Verfahren zur Maschinen- und Prozessqualifikation, Hanser Fachbuchverlag, 2014.
- [19] H. Rinne und K. Specht, Zeitreihen: Statistische Modellierung, Schätzung und Prognose, Vahlen, 2002.
- [20] J. Cryer und K.-S. Chan, Time Series Analysis, Springer, 2008.
- [21] B.-U. Köhler, Konzepte der statistischen Signalverarbeitung, Springer, 2005.
- [22] D. Simon, Optimal State Estimation, WILEY, 2006.
- [23] C. Lackhove, L. Quiroga, F. Ramond, R. Rebai, R. Rivoallan, L. Rousseau und F. Sourd, Nautomain.eu, 2013. [Online]. Available: http://www.automain.eu/IMG/pdf/wp5_d5_1_def.pdf. [Zugriff am 30 06 2014].
- [24] A. Hess, „Prognostics, from the need to reality – from the fleet users and PHM system designer/developers perspectives“, Bd. 6, Piscataway, NJ, IEEE Operations Center, 2002, pp. 6-2791-6-2797 vol.6.
- [25] VDI-Gesellschaft Produktion und Logistik, *Zustandsorientierte Instandhaltung (Maintenance condition monitoring)*, Berlin, 1999.
- [26] H. Wenzel, R. Veit-Egerer und M. Widmann, „The Role of SHM in Civil Lifecycle Engineering“, Germany, 2012, pp. 10-17.
- [27] K. Beck, B. Jäger und K. Lemmer, „Optimisation of point life cycle costs through load-dependent maintenance“, Edinburgh, UK, Engineering Technics Press Edinburgh, 2007.
- [28] T. Böhm, K. Beck, A.-K. Knaak und B. Jäger, „Efficient maintenance strategy through System Dynamics“, Bd. XI, Southampton, WIT, 2008, pp. 755 – 764.
- [29] K. Gutsche und T. Böhm, „Diagnose und Prognose zur erfolgreichen Bewirtschaftung von Eisenbahnanlagen“, *Signal + Draht*, Bd. 103, Nr. 5, pp. 30-34, 2011.
- [30] D. J. Hand, H. Mannila und P. Smyth, Principles of data mining, Cambridge, Mass.: MIT Press, 2001, p. 546.
- [31] S. Kumar, E. Dolev und M. Pecht, „Parameter selection for health monitoring of electronic products“, *Microelectronics Reliability*, Bd. 50, Nr. 2, pp. 161 – 168, 2010.
- [32] R. Betz, R. Hempel und V. Padur, „Architektur eines Managementsystems für wissenschaftliche Daten“, 16 05 2002. [Online]. Available: http://www.dlr.de/sc/Portaldata/15/Resources/dokumente/ws_02/RolfHEMPEL.pdf. [Zugriff am 30 06 2014].

Anhang

1

Begriffsbezeichnung	Erläuterung
Überwachung	VDI-Richtlinie 2651: „Die Überwachung als Funktion teilt sich in Erfassung der Informationen der Assets, Aufbereitung dieser Informationen zu Merkmalen und die anschließende Ableitung von Symptomen anhand von Bezugsgrößen.“
Information	VDI-Richtlinie 2651: „Informationen von oder über physikalische Assets im ersten Schritt können dabei automatisch, im Allgemeinen in analoger oder binärer Form erfasst bzw. auch manuell (z. B. durch Inspektion) eingegeben werden, wobei es sich nicht nur um die Informationen eines einzelnen Asset, sondern auch um die Informationen vieler Assets handeln kann. Die Signalerfassung umfasst einerseits die esstechnische Erfassung von Signalen (eigentliches Messen) und andererseits die Bereitstellung dieser Signale für die weitere Verarbeitung.“
Merkmale	VDI-Richtlinie 2651: „Merkmale werden in der nachfolgenden Informationsaufbereitung erzeugt. Merkmale sind charakteristische Größen, die sich infolge von Einflüssen signifikant verändern und somit eine Beurteilung der Einflüsse als auslösendes Moment erlauben. Merkmale müssen zwangsläufig nicht immer zusätzlich erzeugt werden, da oftmals Signale selbst bereits ein Merkmal darstellen (z. B. die Temperatur der Wicklung eines Motors). Die Bestandteile der Signalaufbereitung zur Merkmalerzeugung sind die Vorverarbeitung, z. B. eine Filterung und die Berechnung relevanter Größen. Dazu zählen z. B. Mittelwertbildung, Zählfunktionen, Berechnung von Minimal- und Maximalwerten, Ableitungen, Frequenzanalyse, Standardabweichung sowie die Berechnung von Größen aus der Kombination mehrerer Signale.“
Diagnose	VDI-Richtlinie 2651: „Die nachfolgende Stufe Diagnose wertet die Symptome als Ausgangsgrößen der Überwachung aus. Folgende Funktionen sollen mit der Diagnose erfüllt werden: <ul style="list-style-type: none"> • Diagnosefindung und Ursachenermittlung: Dazu zählen alle Einflüsse, die das Symptom auslösen. Für diese Einflüsse werden vollständig oder teilweise Informationen in Bezug auf Art, Ort, Ursache und Entstehungszeit ermittelt. • Bewertung: Wenn möglich, werden Aussagen über die Zuverlässigkeit, die Vertrauenswürdigkeit oder die Wahrscheinlichkeit (wie sicher ist gemachte Aussage) gebildet. Dies setzt voraus, dass auch diesbezügliche Aussagen für die zugrunde liegenden Prozessinformationen (Signale der Assets) erzeugt werden.“
Prognose	VDI-Richtlinie 2651: „Nächster Schritt nach der Diagnose ist die Prognose. Im Rahmen der Prognose erfolgt eine Voraussage im Hinblick auf bevorstehende Ausfälle oder Störungen und/oder über die verbleibende Nutzungsdauer. Die Voraussage kann in Abhängigkeit von messbaren physikalischen Zusammenhängen, Regeln und/oder Erfahrungswissen, das sich aus der Kenntnis des Verhaltens dieses Asset oder dieses Asset-Typs aus der Vergangenheit ergibt, erfolgen.“
Symptom	VDI-Richtlinie 2651: „Symptome werden aus Merkmalen durch Vergleich mit Bezugsgrößen abgeleitet. So ist z. B. das Merkmal „Wicklungstemperatur eines Motors“ alleine noch kein Symptom, weil der Absolutwert nichts über eine mögliche Überlastung aussagt. Erst der Vergleich mit dem maximal zulässigen Wert oder einem Bezugswert (z. B. Nennwert) liefert eine Aussage zu einer Abweichung. Symptome können z. B. auf folgende Arten abgeleitet werden: <ul style="list-style-type: none"> • Vergleich mit Soll-, Grenz-, Nenn- oder Erfahrungswerten • Trendüberwachung • Vergleich mit Modellen • statistische Überwachung • Funktionsüberwachung • Plausibilitätsprüfung“
Störung	KoRil 420.9001 S.2: „Störungen sind Abweichungen von betrieblichen Planungen oder definierten Sollzuständen. Sie treten in Prozessabläufen, an technischen Anlagen oder durch Außeneinflüsse auf.“

Tab. A1: Erarbeitete Begriffsdefinition für eine zentrale Diagnoseplattform in Anlehnung an [4]